Prediksi Cuaca Menggunakan Sensor Cahaya, Kecepatan Angin, dan Arah Angin dengan Metode Neuro-Fuzzy

Reynaldi Rizki Billanivo[1], Ricky Maulana Fajri[2], Tasmi[3], Ferdiansyah[4]
[1,2,3,4]Program Studi Sistem Komputer UNIVERSITAS INDO GLOBAL MANDIRI
JL. Jend Sudirman No. 629, Palembang 30129, Sumatera Selatan
Email: 2021310016@students.uigm.ac.id[1], rickymaulanafajri@uigm.ac.id[2],
tasmi@uigm.ac.id[3], ferdi@uigm.ac.id[4]

Abstrak

Prediksi cuaca merupakan elemen yang sangat penting dalam berbagai sektor, termasuk pertanian dan transportasi. Salah satu contohnya adalah membantu petani untuk menunda penanaman tanaman sebelum hujan deras terjadi. Penelitian ini menggunakan metode Neuro-Fuzzy yang dipadukan dengan tiga jenis sensor yakni sensor cahaya, sensor kecepatan angin, dan sensor arah angin, yang digunakan untuk peramalan meteorologi. Penelitian ini memanfaatkan dataset Misol dan dataset BMKG. Model Neuro-Fuzzy mencapai akurasi rata-rata sebesar 0,71, presisi 0,4075, recall 0,3185, dan skor F1 sebesar 0,337.

Kata kunci: prediksi cuaca, *Neuro-Fuzzy*, sensor cahaya, sensor kecepatan angin, sensor arah angin

Abstract

Weather forecasting is a crucial element in multiple sectors, including agriculture and transportation. An example is assisting farmers in refraining from planting crops immediately prior to substantial rainfall. This study employs the Neuro-Fuzzy method alongside three sensor types: a light sensor, a wind speed sensor, and a wind direction sensor, utilized for meteorological forecasting. This study utilizes the Misol dataset and the BMKG dataset. The Neuro-Fuzzy model attained an average accuracy of 0.71, a precision of 0.4075, a recall of 0.3185, and an F1 score of 0.337

Keywords: Weather prediction, Neuro-Fuzzy, light sensor, wind speed sensor, wind direction sensor

1. PENDAHULUAN

Prediksi cuaca sangat penting untuk berbagai industri seperti pertanian, transportasi, dan pariwisata. Sebagai contoh, prediksi cuaca yang akurat dapat membantu petani menghindari menanam tanaman tepat sebelum hujan lebat, yang dapat menyebabkan kehilangan hasil panen [1]. Demikian pula, maskapai penerbangan dapat menyesuaikan jadwal penerbangan berdasarkan prakiraan cuaca untuk mencegah penundaan dan menjaga keselamatan penumpang [2]. Meskipun prakiraan cuaca penting untuk perencanaan, prakiraan cuaca tidak selalu sepenuhnya akurat dan masih dapat mengakibatkan peristiwa cuaca yang tidak terduga yang menyebabkan gangguan [3][4]. Oleh karena itu baik individu maupun perusahaan harus siap menghadapi perubahan cuaca dengan memantau prakiraan cuaca.

Model komputer banyak digunakan untuk prakiraan cuaca, memanfaatkan data dari satelit, Radar, dan stasiun cuaca [5][6]. Namun demikian, model-model ini terkadang dapat mengabaikan aspek-aspek penting, yang mengakibatkan kesalahan [7]. Sebagai contoh, model komputer dapat memprediksi langit yang cerah untuk rute penerbangan, tetapi gagal memperhitungkan sistem badai yang tiba-tiba bergerak [8]. Kekeliruan ini dapat menyebabkan turbulensi yang tidak terduga dan penundaan bagi penumpang meskipun ada prakiraan awal [9]. Terlepas dari kendala-kendala yang ada, prediksi cuaca semakin meningkat melalui teknologi baru [10]. Sebagai contoh, kemajuan dalam kecerdasan buatan dan pembelajaran mesin diintegrasikan ke dalam model prakiraan cuaca untuk meningkatkan akurasi dan keandalan. Selain itu, penggunaan data cuaca beresolusi tinggi dan algoritma yang canggih membantu memprediksi peristiwa cuaca buruk seperti badai dan banjir dengan lebih baik [11].

Untuk meningkatkan ketepatan prediksi cuaca, berbagai teknologi dan metode, termasuk penggunaan sensor dan teknik Neuro-Fuzzy, telah diterapkan. sensor seperti cahaya, kecepatan angin, dan arah angin mengumpulkan data waktu nyata yang memperkaya model cuaca, memberikan informasi penting tentang tutupan awan, variasi suhu, serta intensitas badai dan fluktuasi tekanan udara [12]. Metode Neuro-Fuzzy, yang menggabungkan jaringan saraf tiruan dan Logika Fuzzy, membantu menganalisis data besar dan mengungkap hubungan antar variabel, sehingga meningkatkan akurasi dan keandalan prediksi cuaca [13].

Berdasarkan permasalahan di atas, maka penelitian ini bertujuan untuk menilai kemampuan teknik Neuro-Fuzzy dalam meningkatkan akurasi prediksi cuaca, terutama di daerah rawan cuaca buruk, serta mengidentifikasi pola cuaca yang kompleks dan berkontribusi pada pengembangan metode prediksi yang lebih akurat dan adaptif terhadap kondisi cuaca ekstrem.

2. TINJAUAN PUSTAKA

2.1 Prediksi Cuaca

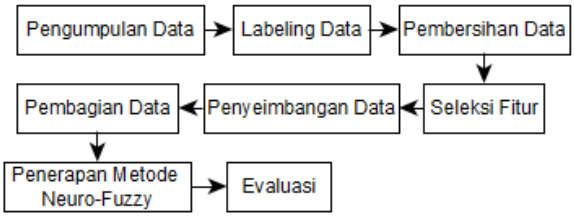
Prediksi cuaca adalah proses ilmiah yang bertujuan untuk memperkirakan kondisi atmosfer di masa depan berdasarkan data meteorologi yang ada. metode ini sangat penting karena dapat memberikan informasi yang krusial untuk berbagai sektor, termasuk pertanian, transportasi, dan mitigasi bencana alam [14]. Dalam konteks ini, berbagai teknik dan algoritma telah dikembangkan untuk meningkatkan akurasi prediksi cuaca, termasuk penggunaan jaringan saraf tiruan (JST), Algoritma Naive Bayes, dan metode Machine Learning lainnya [15].

2.2 Misol Weather Station RS485

Misol Weather Station adalah sistem pengukuran cuaca yang menggunakan protokol komunikasi RS485 untuk mengumpulkan dan mentransmisikan data meteorologi. RS485 adalah standar komunikasi Serial yang memungkinkan pengiriman data jarak jauh dengan kecepatan tinggi dan dapat menghubungkan beberapa perangkat dalam satu jaringan. Dalam konteks stasiun cuaca, penggunaan RS485 sangat penting karena memungkinkan integrasi berbagai sensor yang mengukur parameter seperti suhu, kelembaban, kecepatan angin, dan curah hujan, serta memberikan data secara Real-Time untuk analisis lebih lanjut [16].

3. METODOLOGI PENELITIAN

Penelitian ini menerapkan alur penelitian terstruktur yang terdiri dari delapan tahap: Pengumpulan Data, Labeling Data, Pembersihan Data, Seleksi Fitur, Penyeimbangan Data, Pembagian Data, Penerapan Metode Neuro-Fuzzy, dan Evaluasi. Keseluruhan proses ini diilustrasikan dalam Gambar 1 dan berfungsi sebagai alur metode penelitian.



Gambar 1 Alur Metodologi Penelitian.

Penelitian ini menggunakan data gabungan yang diperoleh dari dua penyedia utama. Data primer, yang dikumpulkan dari wx.mbkmuigm.site, mencatat parameter cuaca yang spesifik untuk wilayah Universitas Indo Global Mandiri (UIGM). Upaya pengumpulan data primer ini berlangsung selama dua bulan, dari 3 Januari hingga 14 Februari 2025, dan terdiri dari 2.730 baris dengan 14 variabel, termasuk catatan waktu, parameter angin, intensitas cahaya, curah hujan, kelembapan, dan suhu. Data sekunder diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) melalui situs web mereka dataonline.bmkg.go.id. Data sekunder ini terdiri dari 2.985 baris data meteorologi yang lebih luas (suhu, angin, kelembapan, curah hujan) untuk wilayah Palembang, mencakup periode dari April 2018 hingga Agustus 2025. Kedua dataset disediakan dalam format CSV dan diintegrasikan untuk melengkapi informasi cuaca regional.

Pemberian label data merupakan langkah awal yang penting dalam analisis prediksi cuaca menggunakan model Neuro-Fuzzy. Proses ini melibatkan penyempurnaan data sensor mentah dengan memberikan label kondisi cuaca spesifik pada setiap entri, sehingga mengubah dataset menjadi format terstruktur yang sesuai untuk pelatihan Neuro-Fuzzy dan pengenalan pola. Studi ini menggunakan dua dataset berbeda, yaitu data primer dan dataset sekunder. Untuk data primer, pendekatan berbasis waktu diterapkan: label “Siang Hari” (06:00 hingga 18:00) ditentukan berdasarkan nilai ambang batas pembacaan sensor cahaya, suhu, dan curah hujan, membedakan antara kondisi cerah, berawan, mendung, dan hujan. Pelabelan pada malam hari (18:00 hingga 06:00) berfokus terutama pada kelembapan dan curah hujan. Sebaliknya, data sekunder menggunakan kriteria berbasis variabel yang lebih sederhana untuk semua waktu, di mana label “Hujan” diberikan untuk curah hujan di atas 0 mm. Kondisi lain, seperti “Cerah,” “Berawan,” dan “Mendung,” ditentukan berdasarkan kombinasi ambang batas suhu dan kelembapan yang berbeda.

Pembersihan data dilakukan untuk memastikan bahwa data yang digunakan untuk melatih model Neuro-Fuzzy bersih dan konsisten. Langkah ini sangat penting untuk mengurangi bias dan mencegah masalah komputasi yang sering timbul akibat duplikasi data atau nilai yang hilang. Langkah pertama yang diambil adalah mengidentifikasi secara sistematis entri yang mengandung catatan duplikat atau nilai Not a Number (NaN). Setelah entri bermasalah ini diidentifikasi, mereka kemudian dihapus dari data untuk menjaga integritas dan kualitas data input untuk pelatihan model selanjutnya.

Proses Seleksi Fitur dilakukan untuk mengidentifikasi himpunan variabel input optimal untuk model Neuro-Fuzzy. Dari data gabungan, fitur spesifik yaitu kecepatan angin, arah angin (dalam derajat), intensitas cahaya, dan label cuaca yang ditetapkan dipilih secara cermat untuk dimasukkan ke dalam pelatihan model. Langkah metodologis ini bertujuan untuk mengurangi kompleksitas data dengan mengesampingkan fitur-fitur yang dianggap kurang esensial atau tidak relevan.

Penyeimbangan data dilakukan melalui teknik Oversampling, menggunakan metode SMOTE (Synthetic Minority Over-sampling Technique), untuk mengatasi masalah ketidakseimbangan kelas yang sering terjadi pada dataset. Prosedur ini sangat penting untuk menyeimbangkan distribusi label kondisi cuaca, di mana SMOTE bekerja dengan menghasilkan sampel sintetis untuk kelas minoritas. Tujuan utama langkah ini adalah untuk mencegah model ANFIS mengalami underfitting atau mengembangkan bias yang kuat terhadap kelas mayoritas.

Pembagian data melibatkan pemisahan dataset yang telah diproses menjadi dua komponen yang terpisah yaitu set pelatihan, yang digunakan untuk melatih dan mengoptimalkan parameter model, dan set pengujian, yang digunakan untuk mengevaluasi akurasi prediksi model pada kondisi cuaca di luar data yang digunakan untuk pelatihan. Sesuai dengan praktik standar, rasio yang

digunakan untuk pembagian ini adalah 80% untuk data pelatihan dan 20% untuk data pengujian.

Metodologi yang digunakan dalam penelitian ini adalah Neuro-Fuzzy. Neuro-Fuzzy merupakan sistem komputasi hibrida yang secara mulus mengintegrasikan prinsip dasar Logika Fuzzy dan Jaringan Saraf Tiruan (JST) untuk mengelola ketidakpastian dan ketidaktepatan dalam data secara efektif. Kombinasi unik ini memfasilitasi pengembangan sistem yang mampu belajar langsung dari data sambil menerapkan penalaran serupa manusia untuk mengambil keputusan berdasarkan aturan Fuzzy. Keunggulan utama sistem Neuro-Fuzzy terletak pada kemampuannya untuk memproses informasi yang tidak lengkap atau ambigu, yang secara signifikan meningkatkan kemampuan pengambilan keputusan dalam berbagai aplikasi, termasuk sistem kontrol, deteksi kesalahan, dan klasifikasi data [14].

Lapisan 1:

Setiap Simpul i pada lapisan ini adalah simpul adaptif dengan fungsi simpul :

$$o1, i = \mu A_i(x)$$
$$o1, i = \mu B_i - 2(y) \quad (1)$$

Dimana X (atau y) adalah masukkan bagi simpul I, dan AI (atau Bi-2) adalah label Bahasa (linguistic label) seperti misalnya “kecil” atau “luas”, dan lain lain.

Lapisan 2:

Setiap Simpul pada lapisan ini bersifat non-adaptif (parameter tetap) yang mempunyai keluaran berupa perkalian dari semua sinyal yang masuk.

$$o2, i = w\ i\ =\ \mu A_i\ (x)\ \mu\ B_i\ (y) \quad (2)$$

Masing – masing keluaran simpul menyatakan derajat pengaktifan dari aturan Fuzzy.

Lapisan 3:

Setiap simpul pada lapisan 3 diberi label N, juga bersifat non-adaptif. Masing – masing simpul menampilkan derajat pengkatifan ternormalisasi.

$$o3, i = \overline{w}\ i\ =\ \frac{w_i}{w_1\ +\ w_2} \quad (3)$$

Apabila dibentuk lebih dari dua aturan, fungsi dapat diperluas dengan membagi wi dengan jumlah total w untuk semua aturan.

Lapisan 4:

Tiap simpul pada lapisan ini berupa simpul adaptif dengan fungsi simpul :

$$o4, i = \overline{w}\ i\ f_i =\ \overline{w}_i\ (p_i\ x\ +\ q_i\ y\ +\ r_i \quad (4)$$

Dimana bar{w} adalah derajat pengaktifan ternormalisasi dari lapisan 3 dan {pi, qi, ri} merupakan jumpunan parameter dari simpul ini.

Lapisan 5

Simpul tunggal pada lapisan ini diberi label Σ yang mana menghitung semua keluaran sebagai penjumlahan dari semua sinyal yang masuk :

Keluaran keseluruhan

$$o5, i = \sum_i \overline{w}_i\ f_i\ \ =\ \frac{\sum_i w_i\ f_i}{\sum_i w_i} \quad (5)$$

Penelitian ini menggunakan enam metrik evaluasi: Akurasi, Presisi, Recall, Skor F1, Skor AUC, dan Kurva ROC.

Akurasi

akurasi adalah ukuran seberapa sering model memberikan prediksi yang benar (baik positif maupun negatif) dibandingkan dengan keseluruhan data.

$$\text{Akurasi}\ =\ \frac{\text{TP}\ +\ \text{TN}}{\text{TP}\ +\ \text{TN}\ +\ \text{FP}\ +\ \text{FN}} \quad (6)$$

Presisi

Presisi mengukur tingkat ketepatan model dalam memprediksi kelas positif, yaitu dari semua data yang diprediksi positif, berapa yang benar-benar positif.

$$\text{Presisi}\ =\ \frac{\text{TP}}{\text{TP}+\ \text{FP}} \quad (7)$$

Recall

Recall mengukur kemampuan model dalam menemukan semua data positif yang sebenarnya ada, yaitu dari semua data positif, berapa yang berhasil diprediksi dengan benar.

$$\text{Recall}\ =\ \frac{\text{TP}}{\text{TP}+\ \text{FN}} \quad (8)$$

Skor F1

Skor F1 adalah ukuran kinerja model yang menggabungkan presisi dan recall dalam satu nilai dengan menggunakan rata-rata harmonis. Skor F1 sangat berguna ketika terdapat ketidakseimbangan jumlah data antar kelas.

$$\text{Skor F1}\ \ =\ 2\ \text{X}\ \frac{\text{Presisi x Recall}}{\text{Presisi}\ +\ \text{Recall}} \quad (9)$$

Receiver Operating Characteristic (ROC)

Receiver Operating Characteristic (ROC) adalah alat analisis yang sangat penting dalam *machine learning*, terutama dalam konteks klasifikasi. ROC *curve* memungkinkan peneliti untuk mengevaluasi performa model dengan jelas, menghubungkan kemungkinan positif yang benar (*True Positive Rate*, TPR) dan kemungkinan positif yang salah (*False Positive Rate*, FPR) pada berbagai ambang batas

$$TPR\ =\ \frac{TP}{TP\ +\ FN} \quad (10)$$

$$FPR\ =\ \frac{FP}{FP\ +\ TN} \quad (11)$$

Area Under Cover

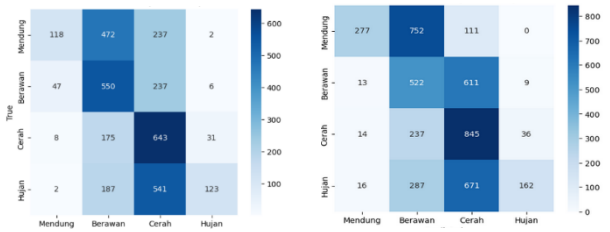
AUC (*Area Under the Curve*) adalah metrik yang sering digunakan dalam evaluasi performa model klasifikasi, khususnya dalam konteks *Receiver Operating Characteristic* (ROC) *curve*. AUC menunjukkan seberapa baik model dapat membedakan antara kelas positif dan negatif. Nilai AUC berkisar antara 0 hingga 1, di mana nilai 1 menunjukkan model yang sempurna dalam klasifikasi dan nilai 0.5 menunjukkan kinerja yang tidak lebih baik daripada tebakan acak.

$$AUC = \int_0^1 TPR\ (FPR)\ dFPR \qquad (12)$$

4. HASIL DAN PEMBAHASAN

4.1 Evaluasi Kinerja Model Neuro-Fuzzy Menggunakan Metode Confusion Matrix

Bagian ini memberikan penilaian komprehensif dan perbandingan terhadap kinerja prediktif Model Neuro-Fuzzy pada data primer dan data sekunder. Kemampuan klasifikasi model dianalisis menggunakan visualisasi *Confusion Matrix* dan dikonfirmasi oleh Metrik Laporan Klasifikasi, termasuk Akurasi, Presisi, *Recall*, dan Skor F1.



(a) (b)

Gambar 2 Confusion Matrix, (a) Data Primer, (b) Data Sekunder.

Tabel 1 Metrik Laporan Klasifikasi.

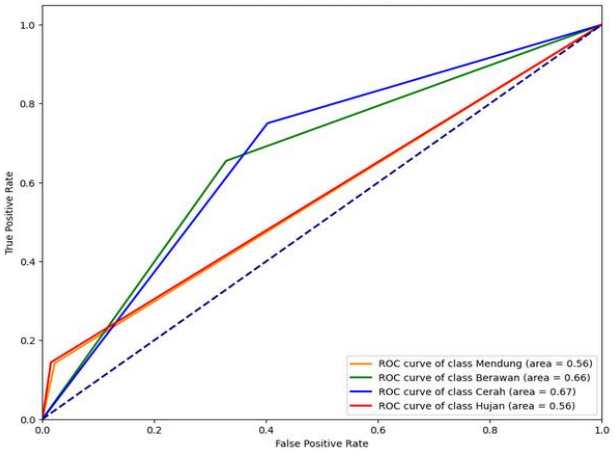
No	Matrix	Primary Data	Secondary Data
1	Accuracy	0,730	0,690
2	Precision	0,424	0,395
3	Recall	0,498	0,147
4	F1 Score	0,458	0,214

Model Neuro-Fuzzy, ketika dievaluasi pada data primer, menunjukkan kinerja yang biasa-biasa saja dalam kapabilitas klasifikasi, meskipun mencapai Akurasi keseluruhan yang rata-rata sebesar 0.730 dalam Tabel 1. Meskipun akurasi ini menunjukkan bahwa 73% dari semua prediksi benar, metrik ini tidak akurat karena model memiliki kelemahan signifikan dalam mengidentifikasi kelas-kelas spesifik. Terutama, model menghasilkan nilai rendah untuk metrik diskriminatif utama, termasuk Presisi sebesar 0,424, Recall sebesar 0,498, dan Skor F1 sebesar 0,458. Nilai Presisi yang rendah menunjukkan tingkat False Positives yang tinggi, artinya model sering membuat pernyataan positif yang salah. Selain itu, analisis *Confusion Matrix* pada Gambar 2 mengonfirmasi kesulitan model dalam menangani batasan kondisi, terutama dalam mengklasifikasikan salah Hujan dan Mendung ke dalam kategori Cerah atau Berawan.

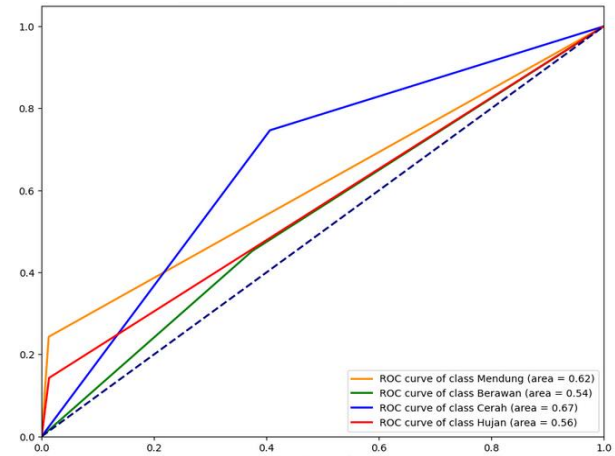
Kinerja model pada data sekunder menunjukkan penurunan yang signifikan dalam kepercayaan. Laporan Klasifikasi pada Tabel 1 menunjukkan akurasi keseluruhan yang lebih rendah sebesar 0.690 dibandingkan dengan data primer. Terutama, kemampuan model untuk mengidentifikasi contoh positif menurun secara signifikan, mengakibatkan presisi yang jauh lebih rendah sebesar 0.395 dan recall yang buruk sebesar 0.147, yang menyebabkan skor F1 turun menjadi hanya 0.214. *Confusion Matrix* pada Gambar 2 mengonfirmasi kegagalan ini, menunjukkan bahwa sebagian besar peristiwa Hujan (Rain) sebenarnya diklasifikasikan secara salah sebagai Cerah (Sunny) atau Berawan (Cloudy).

4.2 Evaluasi Kinerja Model Neuro-Fuzzy Menggunakan AUC *Score* dan ROC *Curve*

Bagian ini berfokus pada evaluasi kemampuan diskriminatif Model Neuro-Fuzzy menggunakan *Area Under the Curve* (AUC) *Score* dan *Receiver Operating Characteristic* (ROC) *Curve*. Metode-metode ini digunakan untuk menilai kinerja model dalam membedakan antara kelas positif dan negatif pada berbagai ambang batas.



(a)



(b)

Gambar 3 ROC, (a) Data Primer, (b) Data Sekunder.

Berdasarkan visualisasi ROC *Curve* untuk data utama pada Gambar 3, skor AUC yang dihasilkan mengonfirmasi daya diskriminatif model yang lemah, terutama untuk kelas-kelas tertentu. Seperti yang ditunjukkan pada gambar, kinerja diskriminatif tertinggi dicapai oleh kelas Cerah (AUC = 0.67) dan kelas Berawan (AUC = 0.66). Namun, model menunjukkan kinerja yang hampir sama dengan tebakan acak untuk kelas Mendung (AUC = 0.56) dan kelas Hujan (AUC = 0.56). Nilai AUC yang mendekati 0.5 menunjukkan bahwa model hanya sedikit lebih baik daripada tebakan acak dalam membedakan kelas-kelas ini dari yang lain.

Evaluasi data sekunder mengonfirmasi bahwa daya diskriminatif model sangat terbatas, seperti yang ditunjukkan oleh kurva ROC. Kelas Cerah mencapai kinerja tertinggi (AUC = 0.67). Namun, daya diskriminasi untuk kelas-kelas lainnya sangat lemah, dengan kelas Berawan (AUC = 0.54) dan kelas Hujan (AUC = 0.56) menghasilkan kinerja hampir setara dengan tingkat kemunculan yang acak. Bahkan kelas Mendung (AUC = 0.62 hanya menunjukkan kinerja yang cukup.

4.3 Pembahasan

Perbandingan kinerja pada kedua dataset menunjukkan bahwa model Neuro-Fuzzy sangat sensitif terhadap sumber data dan jenis fitur. Model ini mencapai kinerja yang lebih baik, meskipun masih lemah, pada data primer (F1 Score 0.458), kemungkinan karena penambahan sensor cahaya sebagai fitur input tambahan yang memberikan informasi lokal. Namun, kinerja pada data sekunder tidak dapat diterima untuk prediksi, ditandai dengan Skor F1 yang hampir gagal sebesar 0,214 dan Recall yang sangat rendah sebesar 0,147. Hasil ini menunjukkan bahwa meskipun metode Neuro-Fuzzy mungkin menunjukkan potensi saat menggunakan data sensor yang sangat spesifik dan lokal, kemampuannya untuk menggeneralisasi data cuaca yang lebih luas sangat terbatas.

5. KESIMPULAN

Penelitian ini bertujuan untuk mengevaluasi kelayakan model Neuro-Fuzzy dalam mengklasifikasikan empat kondisi cuaca yang berbeda, yaitu Berawan, Mendung, Cerah, dan Hujan, menggunakan data sensor lokal dan catatan meteorologi yang lebih luas. Evaluasi menunjukkan bahwa kinerja model sangat tidak konsisten, dengan skor F1 yang buruk sebesar 0,458 pada data primer dan skor F1 yang tidak dapat diterima sebesar 0,214 pada data sekunder. Secara signifikan, skor AUC untuk kelas Hujan yang penting tetap berada pada level hampir acak (0,56) di kedua lingkungan. Oleh karena itu, studi ini menyimpulkan bahwa pendekatan Neuro-Fuzzy, dalam konfigurasi saat ini, sangat sensitif terhadap lingkungan pelatihan dan belum cocok untuk penerapan operasional yang andal.

Penelitian ini dibatasi oleh beberapa keterbatasan utama. Pertama, penelitian ini menggunakan ukuran dataset yang relatif kecil. Kedua, kumpulan fitur yang digunakan sangat terbatas, hanya mengandalkan sensor cahaya, kecepatan angin, dan arah angin. Dan yang terakhir, cakupan metodologis terbatas pada evaluasi metode Neuro-Fuzzy tanpa memasukkan pendekatan machine learning untuk perbandingan.

Penelitian di masa depan disarankan untuk menggunakan jumlah data yang lebih besar. Selanjutnya, kumpulan fitur harus diperluas untuk mencakup data yang lebih kaya, seperti sensor suhu dan kelembaban, dan metode perbandingan, seperti algoritma Random Forest dan Support Vector Machine (SVM), harus digunakan untuk pembandingan terhadap metode Neuro-Fuzzy.

DAFTAR PUSTAKA

[1] S. Defiyanti, B. Nurina Sari, and T. Nur Padilah, "Optimasi Pertanian Padi: Peramalan Curah Hujan Berbasis Arima Untuk Penentuan Waktu Tanam Yang Tepat," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 6, pp. 1377–1384, 2024, doi: 10.25126/jtiik.2024118682.

[2] A. Kwasiborska, M. Grabowski, A. N. Sedláčková, and A. Novák, "The Influence of Visibility on the Opportunity to Perform Flight Operations with Various Categories of the Instrument Landing System," *Sensors*, vol. 23, no. 18, 2023, doi: 10.3390/s23187953.

[3] V. Mazzarella *et al.*, "Is an NWP-Based Nowcasting System Suitable for Aviation Operations?," *Remote Sens.*, vol. 14, no. 18, pp. 1–20, 2022, doi: 10.3390/rs14184440.

[4] P. Rajarajeswari, P. L. S. Kumari, A. S. Lakshmi, S. R. Mugunthan, P. R. Kumar, and P. R. Ananthula, "Simulation based Predictive analysis of Indian Airport transportation system using Computational intelligence techniques," *J. Aerosp. Technol. Manag.*, vol. 15, no. i, 2023, doi: 10.1590/jatm.v15.1300.

[5] D. C. Dowell *et al.*, "The High-Resolution Rapid Refresh (HRRR): An Hourly Updating Convection-Allowing Forecast Model. Part I: Motivation and System Description," *Weather Forecast.*, vol. 37, no. 8, pp. 1371–1395, 2022, doi: 10.1175/WAF-D-21-0151.1.

[6] R. Singh, S. P. Ojha, R. Anthes, and D. Hunt, "Evaluation and Assimilation of the COSMIC-2 Radio Occultation Constellation Observed Atmospheric Refractivity in the WRF Data Assimilation System," *J. Geophys. Res. Atmos.*, vol. 126, no. 18, 2021, doi: 10.1029/2021JD034935.

[7] M. Bonavita, "On Some Limitations of Current Machine Learning Weather Prediction Models," *Geophys. Res. Lett.*, vol. 51, no. 12, 2024, doi: 10.1029/2023GL107377.

[8] D. Ziakkas, K. Pechlivanis, and A. Flores, "Role of AI in weather prediction, flight planning, route optimization and scheduling.," *Intell. Hum. Syst. Integr. (IHSI 2024) Integr. People Intell. Syst.*, vol. 119, no. Ihsi, pp. 421–428, 2024, doi: 10.54941/ahfe1004506.

[9] H. H. Shin, W. Deierling, and R. Sharman, "A Comparative Study of Various Approaches for Producing Probabilistic Forecasts of Upper-Level Aviation Turbulence," *Weather Forecast.*, vol. 38, no. 1, pp. 139–161, 2023, doi: 10.1175/WAF-D-22-0086.1.

[10] J. Leinonen, U. Hamann, I. V. Sideris, and U. Germann, "Thunderstorm Nowcasting With Deep Learning: A Multi-Hazard Data Fusion Model," *Geophys. Res. Lett.*, vol. 50, no. 8, 2023, doi: 10.1029/2022GL101626.

[11] J. Hu *et al.*, "Evaluation of an experimental Warn-on-Forecast 3DVAR analysis and forecast system on quasi-real-time short-term forecasts of high-

impact weather events," *Q. J. R. Meteorol. Soc.*, vol. 147, no. 741, pp. 4063–4082, 2021, doi: 10.1002/qj.4168.

[12] S. Ispramono Hadi, E. Ermatita, and N. Chamidah, "Penerapan Fuzzy C-Means dan Fuzzy Sugeno dalam Memprediksi Cuaca," *Inform. J. Ilmu Komput.*, vol. 18, no. 1, p. 11, 2022, doi: 10.52958/iftk.v17i4.4103.

[13] M. U. M. Rao, "Monthly Average Rainfall Forecasting Based On An Adaptive Neuro-Fuzzy Inference System in Upper Brahmani Basin , Odisha , India," pp. 1–20, 2022.

[14] D. R. Rochmawati, "Prediksi Cuaca Dengan Jaringan Syaraf Tiruan Menggunakan Python," *J. Teknol. Komput. dan Inform.*, vol. 2, no. 2, pp. 162–171, 2024, doi: 10.59820/tekomin.v2i2.228.

[15] A. Nur Kirana, B. Nurhakim, S. Eka Permana, W. Prihartono, and G. Dwilestari, "Implementasi Algoritma Naive Bayes Untuk Memprediksi Cuaca Menggunakan Rapidminer," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 2, pp. 1637–1642, 2024, doi: 10.36040/jati.v8i2.8967.

[16] N. H. Mamat, H. A. Shazali, and W. Z. Othman, "Development of a Weather Station with Water Level and Waterflow Detection using Arduino," *J. Phys. Conf. Ser.*, vol. 2319, no. 1, 2022, doi: 10.1088/1742-6596/2319/1/012020.